下载APP

16 套路篇 | 如何分析常见的TCP问题?

2020-09-24 邵亚方

Linux内核技术实战课 进入课程 >

讲述：邵亚方
时长 11:58　大小 10.98M

你好，我是邵亚方。

对互联网服务而言， 网络问题是非常多的，而且很多问题的外在表现都是网络问题，这就需要我们从网络入手，分析清楚根本原因是什么。而要分析各种各样的网络问题，你必须掌握一些分析手段，这样在出现问题的时候，你就可以高效地找到原因。这节课我就带你来了解下 TCP 的常见问题，以及对应的分析套路。

在 Linux 上检查网络的常用工具

当服务器产生问题，而我们又不清楚问题和什么有关时，就需要运行一些工具来检查系统的整体状况。其中，dstat 是我们常用的一种检查工具：

复制代码

```
$ dstat
--total-cpu-usage-- -dsk/total- -net/total- ---paging-- ---system--
usr sys idl wai stl| read  writ| recv  send|  in   out | int   csw
  8   1  91   0   0|   0  4096B|7492B 7757B|   0     0 |4029  7399
  8   1  91   0   0|   0     0 |7245B 7276B|   0     0 |4049  6967
  8   1  91   0   0|   0   144k|7148B 7386B|   0     0 |3896  6971
  9   2  89   0   0|   0     0 |7397B 7285B|   0     0 |4611  7426
  8   1  91   0   0|   0     0 |7294B 7258B|   0     0 |3976  7062
```

如上所示，dstat 会显示四类系统资源的整体使用情况和两个关键的系统指标。这四类系统资源分别是：CPU、磁盘 I/O、 网络和内存。两个关键的系统指标是中断次数（int）和上下文切换次数（csw）。而每个系统资源又会输出它的一些关键指标，这里你需要注意以下几点：

分类	注意项
CPU（total-cpu-usage）	CPU的使用率。包括用户占比（usr）、系统占比（sys）、空闲占比（idl）、IO等待占比（wai）、虚拟机运行占比（stl）。这里你要特别注意sys和wai这两项，如果它们很高，就意味着系统出问题了。
磁盘（dsk）	磁盘吞吐，包括读（read）和write（写），如果读写量很大的话，你就需要使用iostat再去针对性地看下I/O指标是否存在异常。比如ioutil太高，那就说明磁盘能力满足不了业务需求了；如果avgqu-sz太大的话，那极有可能出现读被写给饿死的情况。
网络（net）	网络吞吐，包括收包（recv）和发包（send）。如果吞吐太高，那你需要去留意下网卡中断，包括软中断和硬中断，中断太多对业务性能可能会造成一些影响。
内存（paging）	分页统计信息，包括读入（page in）和读出（page out）。针对这部分，你可以重点看下我们这个课程第一个模块里讲的内容，那里有很详细的注意事项。

如果你发现某一类系统资源对应的指标比较高，你就需要进一步针对该系统资源做更深入的分析。假设你发现网络吞吐比较高，那就继续观察网络的相关指标，你可以用 dstat -h 来查看，比如针对 TCP，就可以使用 dstat -tcp：

复制代码

```
$ dstat --tcp
------tcp-sockets-------
lis  act  syn  tim  clo
  27   38    0    0    0
  27   38    0    0    0
```

它会统计并显示系统中所有的 TCP 连接状态，这些指标的含义如下：

TCP指标	含义
lis	处于监听（Listen）状态的连接数，比如上面的输出显示总共有27个处于监听状态的连接。
act	处于已连接（ESTABLISHED）状态的连接数，比如上面的输出显示总共有38个已经建立好的连接。
syn	处于三次握手阶段的连接数。如果该指标过大，往往意味这瞬间有大量的TCP新建连接请求，这是很容易产生问题的，需要你格外注意。
tim	处于TIME-WAIT状态的连接数。
clo	处于CLOSE-WAIT状态的连接数。这一项如果太多，往往意味着应用程序存在代码bug，没有去主动调用close(2)来关闭这些连接，这种问题是互联网服务中很常见的问题。

在得到了 TCP 连接的整体状况后，如果你想要看 TCP 连接的详细信息，你可以使用 ss 这个命令来继续观察。通过 ss 你可以查看到每个 TCP 连接都是什么样的：

复制代码

```
$ ss -natp
State          Recv-Q         Send-Q                                  Loca
LISTEN0        100                                  0.0.0.0:36457         0.0.0.
LISTEN0        5                                    0.0.0.0:33811         0.0.0.
ESTAB 0        0                                  127.0.0.1:57396       127.0.1.
ESTAB 0        0                                  127.0.0.1:57384       127.0.1.
```

如上所示，我们能查看到每个 TCP 连接的状态（State）、接收队列大小（Recv-Q）、发送队列大小（Send-Q）、本地 IP 和端口（Local Address:Port ）、远端 IP 和端口（Peer Address:Port）以及打开该 TCP 连接的进程信息。

除了 ss 命令外，你也可以使用 netstat 命令来查看所有 TCP 连接的详细信息：

复制代码

```
$ netstat -natp
```

不过，我不建议你使用 netstat，最好还是用 ss。因为 netstat 不仅比 ss 慢，而且开销也大。netstat 是通过直接读取 /proc/net/ 下面的文件来解析网络连接信息的；而 ss 使用的是 netlink 方式，这种方式的效率会高很多。

netlink 在解析时会依赖内核的一些诊断模块，比如解析 TCP 信息就需要 tcp_diag 这个诊断模块。如果诊断模块不存在，那么 ss 就无法使用 netlink 这种方式了，这个时候它就会退化到和 netstat 一样，也就是使用解析 /proc/net/ 这种方式，当然了，它的效率也会相应变差。

另外，如果你去看 netstat 手册，通过 man netstat，你会发现这样一句话“This program is obsolete. Replacement for netstat is ss”。所以，以后在分析网络连接问题时，我们尽量还是使用 ss，而不是 netstat。

netstat 属于 net-tools 这个比较古老的工具集，而 ss 属于 iproute2 这个工具集。net-tools 中的常用命令，几乎都可以用 iproute2 中的新命令来代替，比如：

net-tools	iproute2	作用
ifconfig	ip addr; ip link	网络接口具体配置信息。
route; netstat –r	ip route	路由信息, 看看是否有不合理的路由。
netstat	ss	网络连接统计信息。
netstat –s	nstat	网络状态统计信息。

除了查看系统中的网络连接信息外，我们有时候还需要去查看系统的网络状态，比如说系统中是否存在丢包，以及是什么原因引起了丢包，这时候我们就需要 netstat -s 或者它的替代工具 nstat 了：

复制代码

```
$ nstat -z | grep -i drop
TcpExtLockDroppedIcmps          0                  0.0
TcpExtListenDrops               0                  0.0
TcpExtTCPBacklogDrop            0                  0.0
TcpExtPFMemallocDrop            0                  0.0
TcpExtTCPMinTTLDrop             0                  0.0
TcpExtTCPDeferAcceptDrop        0                  0.0
```

```
 8 TcpExtTCPReqQFullDrop          0                  0.0
 9 TcpExtTCPOFODrop               0                  0.0
10 TcpExtTCPZeroWindowDrop        0                  0.0
11 TcpExtTCPRcvQDrop              0                  0.0
```

上面输出的这些信息就包括了常见的丢包原因，因为我的这台主机很稳定，所以你可以看到输出的结果都是 0。

假如你通过这些常规检查手段没有发现异常，那你就需要考虑使用网络分析的必备工具——tcpdump 了。

分析网络问题你必须要掌握的工具：tcpdump

tcpdump 的使用技巧有很多，在这里我们不讲述这些使用技巧，而是讲述一下它的工作原理，以便于你理解 tcpdump 到底在干什么，以及它能够分析什么样的问题。

tcpdump 的大致原理如下图所示：

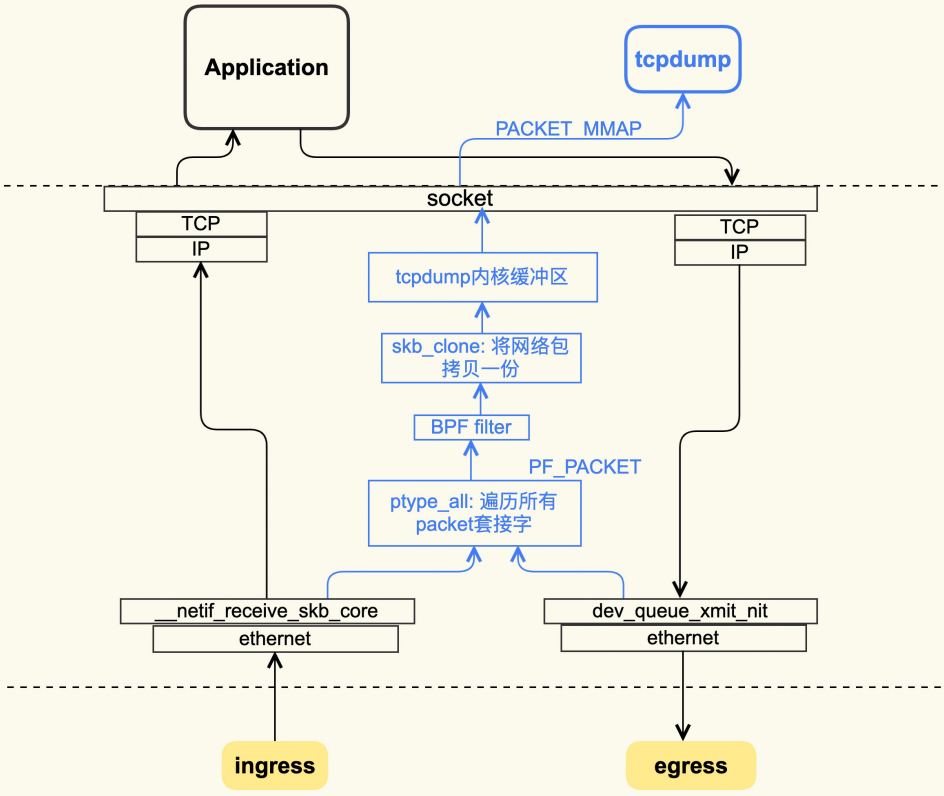

tcpdump基本原理

tcpdump 抓包使用的是 libpacp 这种机制。它的大致原理是：在收发包时，如果该包符合 tcpdump 设置的规则（BPF filter），那么该网络包就会被拷贝一份到 tcpdump 的内核缓冲区，然后以 PACKET_MMAP 的方式将这部分内存映射到 tcpdump 用户空间，解析后就会把这些内容给输出了。

通过上图你也可以看到，在收包的时候，如果网络包已经被网卡丢弃了，那么 tcpdump 是抓不到它的；在发包的时候，如果网络包在协议栈里被丢弃了，比如因为发送缓冲区满而被丢弃，tcpdump 同样抓不到它。我们可以将 tcpdump 的能力范围简单地总结为：网卡以内的问题可以交给 tcpdump 来处理；对于网卡以外（包括网卡上）的问题，tcpdump 可能就捉襟见肘了。这个时候，你需要在对端也使用 tcpdump 来抓包。

你还需要知道一点，那就是 tcpdump 的开销比较大，这主要在于 BPF 过滤器。如果系统中存在非常多的 TCP 连接，那么这个过滤的过程是非常耗时的，所以在生产环境中要慎用。但是，在出现网络问题时，如果你真的没有什么排查思路，那就想办法使用 tcpdump 来抓一下包吧，也许它的输出会给你带来一些意外的惊喜。

如果生产环境上运行着很重要的业务，你不敢使用 tcpdump 来抓包，那你就得去研究一些更加轻量级的追踪方式了。接下来，我给你推荐的轻量级追踪方式是 TCP Tracepoints。

TCP 疑难问题的轻量级分析手段：TCP Tracepoints

Tracepoint 是我分析问题常用的手段之一，在遇到一些疑难问题时，我通常都会把一些相关的 Tracepoint 打开，把 Tracepoint 输出的内容保存起来，然后再在线下环境中分析。通常，我会写一些 Python 脚本来分析这些内容，毕竟 Python 在数据分析上还是很方便的。

对于 TCP 的相关问题，我也习惯使用这些 TCP Tracepoints 来分析问题。要想使用这些 Tracepoints，你的内核版本需要为 4.16 及以上。这些常用的 TCP Tracepoints 路径位于 /sys/kernel/debug/tracing/events/tcp/ 和 /sys/kernel/debug/tracing/events/sock/，它们的作用如下表所示：

TCP Tracepoint	作用
tcp_retransmit_skb	用来追踪TCP重传信息，我在“15讲“里介绍过这个Tracepoint，你可以去温习一下。
tcp_retransmit_synack	前一个Tracepoint无法追踪半连接的重传，即SYN-ACK包的重传是无法追踪的，该Tracepoints可以来追踪这种类型的重传。
tcp_rcv_space_adjust	当数据从内核空间拷贝到用户空间的时候，会执行该Tracepoint。所以，我们可以根据这个Tracepoint来判断数据包是否在内核缓冲区里阻塞太久了，它可以帮助我们判断一些网络延迟是应用自身导致的，还是内核导致的。
tcp_probe	这个Tracepoint可以用来追踪TCP拥塞控制，关于这个Tracepoint，你可以参考“13讲”里的内容。
tcp_send_reset	该Tracepoint可以用来追踪发送的RST包。
tcp_receive_reset	该Tracepoint可以用来追踪接收到的RST包。
tcp_destroy_sock	用来追踪一个TCP连接的销毁。
inet_sock_set_state	该Tracepoint用以追踪网络连接的状态变化，比如一个TCP连接从三次握手到建连完成，再到四次回收的这个过程。

这里多说两句，表格里的 tcp_rcv_space_adjust 是我在分析 RT 抖动问题时贡献给内核的，具体你可以看 net: introduce a new tracepoint for tcp_rcv_space_adjust这个 commit。还有 inet_sock_set_state，该 Tracepoint 也是我贡献给 Linux 内核的，具体可详见 net: tracepoint: replace tcp_set_state tracepoint with inet_sock_set_state tracepoint。其实我对“inet_sock_set_state”这个名字不太满意，本来想使用“inet_sk_set_state”来命名的，因为后者更精炼，但是为了更好地匹配内核里的 struct inet_sock 结构体，我还是选择了现在这个略显臃肿的名字。

我们回到 TCP Tracepoints 这一轻量级的追踪方式。有一篇文章对它讲解得很好，就是 Brendan Gregg 写的 TCP Tracepoints，这里面还详细介绍了基于 Tracepoints 的一些工具，如果你觉得用 Python 脚本解析 TCP Tracepoints 的输出有点麻烦，你可以直接使用里面推荐的那些工具。不过，你需要注意的是，这些工具都是基于 ebpf 来实现的，而 ebpf 有一个缺点，就是它在加载的时候 CPU 开销有些大。这是因为有一些编译工作比较消耗 CPU，所以你在使用这些命令时要先看下你的系统 CPU 使用情况。当 ebpf 加载起来后，CPU 开销就很小了，大致在 1% 以内。在停止 ebpf 工具的追踪时，也会有一些 CPU 开销，不过这个开销比加载时消耗的要小很多，但是你同样需要注意一下，以免影响到业务。

相比于 tcpdump 的臃肿，这些 TCP Tracepoints 就很轻量级了，你有必要用一用它们。

好了， 我们这节课就讲到这里。

课堂总结

我们讲了 TCP 问题分析的惯用套路，我再次强调一下这节课的重点：

尽量不要使用 netstat 命令，而是多使用它的替代品 ss，因为 ss 的性能开销更小，运行也更快；

当你面对网络问题一筹莫展时，可以考虑使用 tcpdump 抓包看看，当系统中的网络连接数较大时，它对系统性能会产生比较明显的影响，所以你需要想办法避免它给业务带来实质影响；

TCP Tracepoints 是比较轻量级的分析方案，你需要去了解它们，最好试着去用一下它们。

课后作业

请问 tcpdump 在解析内核缓冲区里的数据时，为什么使用 PACKET_MMAP 这种方式？你了解这种方式吗？这样做的好处是什么？欢迎你在留言区与我讨论。

感谢你的阅读，如果你认为这节课的内容有收获，也欢迎把它分享给你的朋友，我们下一讲见。

提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 15 分析篇 | 如何高效地分析TCP重传问题?

下一篇 17 基础篇 | CPU是如何执行任务的?

精选留言 (4)

写留言

邵亚方 置顶

2020-10-11

课后作业答案：
- 请问 tcpdump 在解析内核缓冲区里的数据时，为什么使用 PACKET_MMAP 这种方式？你了解这种方式吗？这样做的好处是什么？
评论区有同学已经回答的很好了，
“PACKET_MMAP减少了系统调用，不用recvmsg就可以读取到捕获的报文，相比原始...

展开

0xFE

2020-09-24

PACKET_MMAP减少了系统调用，不用recvmsg就可以读取到捕获的报文，相比原始套接

字+recvfrom的方式，减少了一次拷贝和一次系统调用。

展开

1 2

那时刻

2020-09-24

请问老师Wireshark和tcpdump在实现原理上，是否也是监控网卡以内的行为？

作者回复: wireshark跟tcpdump原理是一致的，都是在网卡软中断里抓包的，自然就无法抓取网卡里的错误，所以通常情况下都需要在两端同时抓包来比较。理解工具的原理要比会用工具更加重要。

0xFE

2020-09-24

1.感谢作者的总结，请教下ss命令或者读proc文件会进行加锁吗？如果会是否影响性能。proc下的meminfo会
2.bpf的性能好和tcpdump的性能差，如何理解。是否
3.后续会出实际的tracepoint或者stap之类的实际案件排查吗？

展开

作者回复: 1.会有锁，而且可能还会关中断，这可能会引起业务网络抖动，我们后面课程里有这方面的案例。
2. ebpf通常情况下性能损耗要小一些，因为他在内核里会进行处理，省去了很多无谓的流程开销，或者说它更有针对性，针对某个特定点来追踪，那么这个点之外的逻辑就不会受影响；而tcpdump一是处理流程长，更耗时，二是它不具有针对性，分析面广，这就导致它的开销大。
3. 这类案例的分析会更偏内核实现，比如借助tracepoint来观察内存申请细节，从tracepoint可以观察到gfp_nofs为什么会引起compact fail，然而这类案例对应用开发者或者运维人员太难了，因为很少有人知道gfs_nofs是什么，甚至很多内核开发者都不清楚. 所以这个课程里我会有意的忽略这些内核实现细节，降低内核的门槛，让更多的人更容易了解内核。不过在加餐篇里会有这方面的一些案例，因为我们这门课还是有内核开发者来看的。

1